

Braunschweigische
Wissenschaftliche Gesellschaft

Jahrbuch 2017

Sonderdruck
Seiten 80–88



J. CRAMER Verlag • Braunschweig
2018

Analyse von Mobilitätsdaten*

MONIKA SESTER

Institut für Kartographie und Geoinformatik

Gottfried Wilhelm Leibniz Universität , Hannover, Appelstraße 9 a, DE-30167 Hannover

E-Mail: monika.sester@ikg.uni-hannover.de

Zusammenfassung:

Die zunehmende Verfügbarkeit von Geräten zur Erfassung der Position bewegter Objekte (und weiterer Umgebungsinformationen) führt zu einer sehr großen Anzahl und Vielfalt von Mobilitätsdaten. Um daraus wichtige Informationen über die Objekte, ihr Verhalten bzw. die Umgebung der Objekte zu erhalten, ist eine automatische Analyse erforderlich. Im Beitrag werden schlaglichtartig aktuelle Forschungsfragen im Kontext der Analyse von Mobilitätsdaten beleuchtet und anhand von Arbeiten am Institut für Kartographie und Geoinformatik dargestellt.

1. Einführung und Übersicht

Mobilitätsdaten liegen in der Regel in Form von sogenannten Trajektorien vor, d.h. Abfolgen von einzelnen 2D- bzw. 3D-Punkten mit Zeitstempel. Auf diese Weise kann z.B. der zurückgelegte Weg eines Wanderers dokumentiert werden, die Bewegung eines Vogels oder eines Fußballspielers. Erfasst werden die Trajektorien mittels GPS-Sensoren oder durch Beobachtung und Objektverfolgung mit Kameras. Neben der reinen Erfassung der Trajektorie können durch zusätzliche Sensorik noch weitere Informationen aufgenommen werden. Ein prominentes Beispiel hierfür sind sog. Mobile Mapping Fahrzeuge, welche in der Regel aus einer hochgenauen Positionierungseinheit bestehen, die die Trajektorien aber zusätzlich auch die Orientierungsinformationen erfassen, und zusätzliche Sensoren umfassen: Laserscanner, Kameras. Im Kontext der Verarbeitung von Mobilitätsdaten ergeben sich eine Reihe von interessanten und komplexen Fragestellungen, u.a.:

* Der Vortrag wurde am 13.10.2017 vor der Planarversammlung der Braunschweigischen Wissenschaftlichen Gesellschaft gehalten.

- Verbesserung und Fusionierung der Daten: durch Messungen zu verschiedenen Zeitpunkten bzw. Messungen mit verschiedenen Sensoren entstehen große, redundante Datensätze der Umgebung
- Interpretation der Umgebungsinformation zur Bestimmung der Dynamik der Objekte in der Umgebung
- Interpretation der Bewegungsdaten zur Bestimmung von Verhalten

Im Folgenden wird auf diese Fragestellungen kurz eingegangen und anhand von Abbildungen veranschaulicht.

2. Erfassung von Umgebungsinformation

Das Mobile Mapping System des ikg erfasst mit dem Laserscanner pro Sekunde potentiell 600.000 3D-Punkte; hinzu kommen Bilder der vier in verschiedene Richtungen blickenden Kameras. Die Genauigkeit einer einzelnen Lasermessung liegt bei 2cm. Die Positionierung und Orientierung des Fahrzeugs erfolgt mittels einer hochgenauen GPS-IMU (Inertial Measurement Unit). In hochdynamischen Situationen (fließender Verkehr, normale Geschwindigkeiten) können hiermit ca. 20cm absolute Positionsgenauigkeiten erreicht werden. Diese Genauigkeiten sind für viele Fragestellungen bereits ausreichend. Will man hingegen Veränderungen in der Umgebung detektieren, müssen Meßfahrten zu mehreren Zeitpunkten möglichst exakt übereinandergebracht und analysiert werden. Ungenauigkeiten im Bereich von 20cm führen dabei zu Schwierigkeiten bei der Analyse von realen Veränderungen. Daher wurde am ikg ein Verfahren entwickelt, welches in der Lage ist, Scanfahrten zu beliebigen verschiedenen Zeitpunkten zusammenzuführen. Dies wird durch einen globalen Optimierungsansatz durchgeführt, bei dem anhand stabiler Objekte im Objektraum die Trajektorie so adaptiert wird, dass zusammengehörige Punkte aus verschiedenen Messfahrten optimal zusammenpassen. Die globale Optimierung von potentiell sehr großen Datenbeständen kann erreicht werden, indem das Problem zerlegt und in einem Hadoop-Framework berechnet wird (Brenner, 2016). Abb. 1 zeigt die Überlagerung zweier Datensätze, die im Abstand von einem Jahr aufgenommen wurden. Die Abweichungen der Punkte vor der Ausgleichung liegen bei ca. 20cm, danach bei 2cm. In der Ausgleichung wurden 304.748.078 Punkte verarbeitet und dabei 21.300 Unbekannte (= 7.1 km Trajektorie) bestimmt.

Nach der Anpassung lassen sich zum einen hochverdichtete und hochgenaue Punktwolken erzeugen (siehe Abb. 2). Es ist sehr schön zu sehen, welch enormer Detailgrad in den Daten erkennbar ist: Mauerwerk, Pflaster, Straßenzustand.

Darüber hinaus lassen sich Veränderungen zwischen den Meßfahrten präzise erfassen. Dies ist in Abb. 3 dargestellt: relevante Änderungen im Bereich größer 2cm zeigen sich in rot bzw. blau. Rauschhafte Änderungen zeigen sich in der




Abb. 1: Vergleich der Punkte vor und nach der Ausgleichung: Abweichungen davor liegen bei ca. 20cm, danach bei 2 cm (rot: 20cm – blau: 2cm).




Abb. 2: links: Bild einer Scanfahrt; Mitte: Einfache Überlagerung mehrerer Scanfahrten; rechts: Ergebnis der Fusion.




Abb. 3: (links) in rot und blau zeigen sich Veränderungen zwischen den Aufnahmen, z.B. steht der blaue Streifen auf der Straße für eine Eisenplatte, die im Zuge einer Baustelle verlegt wurde (rechts).

Vegetation; größere Abweichungen geben Hinweise auf bauliche Veränderungen wie eine Baustelle.

Im Kontext dieser Forschung ergeben sich weitere Fragen, die im Rahmen von Doktorarbeiten am ikg bearbeitet werden, beispielsweise die automatische Klassifikation der Änderungen (Änderungsarten, -frequenzen) (Schachtschneider et al., 2017) oder die Nutzung von geeigneten Umgebungsinformationen (stabile Objekte wie Fassaden, Pfosten) für autonomes Fahren (Schlichting & Brenner, 2016).

3. Dynamische Parkplatzkarten durch Crowd-Sensing

Eine wichtige Anforderung im Kontext autonomes Fahren ist es, die Dynamik der Umgebung in künftigen Karten festzuhalten. Damit wird es möglich, dass das autonome Fahrzeug eine „Erwartungshaltung“ über seine Umgebung bekommt und diese somit leichter und zuverlässiger mit seinen Sensoren abgleichen kann. In diesem Kontext wurde im Rahmen einer Dissertation untersucht, wie die Dynamik von Parkplatzbelegungen erfasst und analysiert werden kann (Bock et al., 2015). Hierzu wurden in einer Messkampagne an einem Tag 11 Fahrten derselben Strecke unternommen. In den erfassten 3D-Punktwolken wurden mittels Verfahren des Maschinellen Lernens automatisch Fahrzeuge klassifiziert und detektiert und daraus die Belegung im Tagesverlauf analysiert. Abb. 4 zeigt den Prozess der Erfassung, Segmentierung und Klassifizierung der Punktwolke, sowie die entstandene Parkplatzbelegungskarte.

Hieraus lassen sich typische Parkplatzbelegungsverläufe ermitteln, welche in Abb. 5 dargestellt werden.

Es wird deutlich, dass im Stadtzentrum (grün, rot) morgens ein Anstieg der Parkplatzbelegung zu verzeichnen ist, der gegen Abend wieder abfällt. Im Wohngebiet hingegen (Nordstadt), ist das Verhalten genau umgekehrt.

Grundsätzlich konnte im Rahmen der Dissertation gezeigt werden, dass die Parkplatzdynamik sich mittels sog. Crowd-Sensing erfassen lässt, d.h. durch die standardmäßig verbauten Sensoren zukünftiger Fahrzeuge. Beispielsweise wurde nachgewiesen, dass Taxis in San Francisco das Parkverhalten sehr gut abbilden können, wodurch es auch möglich ist, präzisere Prognosen zur Verfügbarkeit von Parkplätzen zu machen (Bock & DiMartino, 2017).

4. Bestimmung von Bewegungsverhalten mobiler Objekte

Aus Bewegungstrajektorien lassen sich Rückschlüsse auf das zugrundeliegende Verhalten des bewegten Objekts schließen. Im Rahmen einer Arbeit am ikg wurde untersucht, in wie weit aus einer Fahrzeugtrajektorie abgeleitet werden kann,

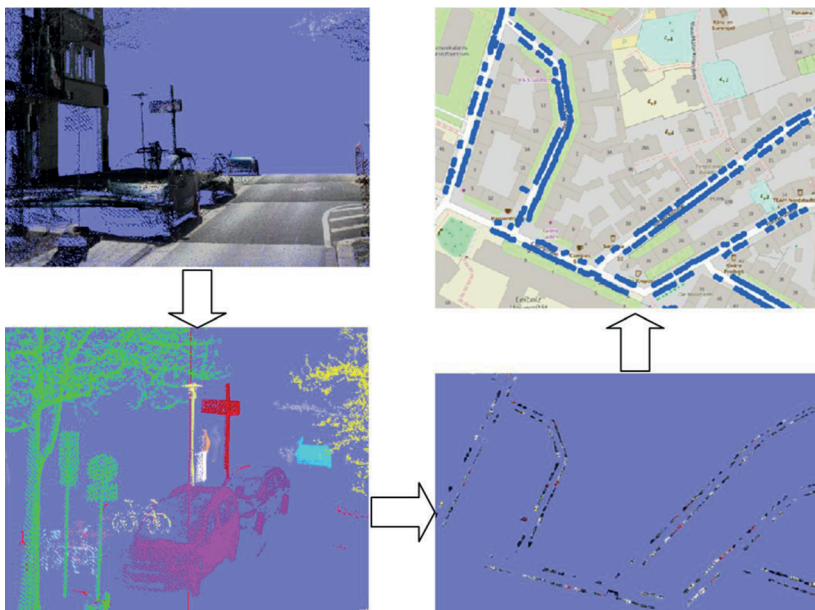


Abb. 4: Abfolge: Punktwolke – Segmentierung der Punktwolke in zusammenhängende Einheiten – Klassifizierung der Einheiten in Autos und Extraktion der Autos – Belegungskarte .




Abb. 5: Belegung der Parkplätze im Tagesverlauf.




Abb. 6: Vertrauen (belief) in anomales Verhalten beim Befahren der Route (links).

ob der Fahrer ein typisches, normales Verhalten zeigt, oder ob sein Verhalten ungewöhnlich ist und darauf hindeutet, dass er sich möglicherweise verfahren hat und Hilfe benötigt. Der Ansatz von Huang et al. nutzt einen Bayes-Ansatz, um anomales Verhalten zu detektieren (Huang et al., 2014). Die Grundidee dabei ist, dass ein verunsicherter Fahrer verschiedene Verhaltensmuster zeigt, wie z. B. falsches Abbiegen, Umwege fahren, dieselbe Strecke nochmals durchfahren. Im Ansatz wird daher das ungewöhnliche Verhalten als Komposition von drei Elementen beschrieben: 1. (dichte Abfolge von) Abbiegungen, 2. Umwege, und 3. Routen-Wiederholung. Diese Merkmale werden aus den Trajektorien extrahiert und mittels eines Markovmodells analysiert. Abb. 6 zeigt links eine Trajektorie, die von unten nach oben befahren wurde. Farblich wird gekennzeichnet, wie hoch das Vertrauen in ungewöhnliches Verhalten ist. Anomales Verhalten wird vermutet, sobald der Verkehrsteilnehmer dieselbe Strecke nochmals befährt.

Neben der Analyse individueller Trajektorien ist es auch möglich, kollektives Verhalten zu analysieren und daraus Rückschlüsse zu ziehen: wenn viele Verkehrsteilnehmer ähnliches, ungewöhnliches Verhalten aufzeigen, ist dies möglicherweise ein Hinweis auf eine Störung im Verkehr. Dies ist in Abb. 7 zu sehen, wo eine Straßensperrung zu ungewöhnlichem Verhalten in der Umgebung führt.

5. Erstellen einer Gefahrenkarte und ihre Nutzung für autonome Fahrzeuge

Wie oben ausgeführt benötigen autonome Fahrzeuge präzise Karten ihrer Umgebung, um darin zu navigieren. Darüber hinaus ist zusätzliche Information erforderlich, die dem Fahrzeug vermittelt, mit welchen Situationen es möglicherweise rechnen muss. Dies kann durch sogenannte Verhaltenskarten oder auch Gefahrenkarten erreicht werden (Busch et al., 2017). Darin sind Bereiche markiert, in

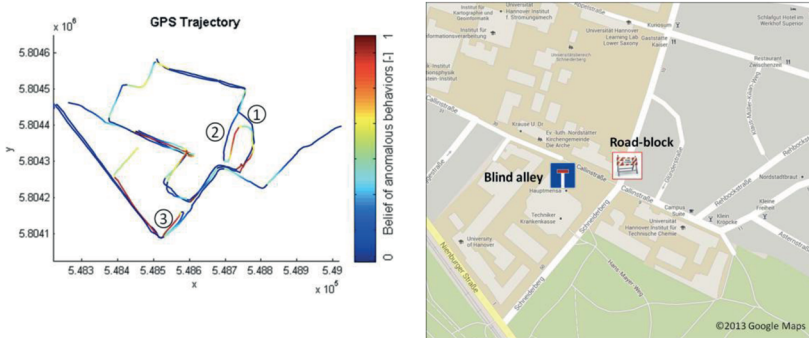


Abb. 7: Beispiel für kollektives Verhalten zur Detektion einer blockierten Straße.



Abb. 8: In den Punktwolken bilden sich Fußgänger ab (links); diese werden automatisch klassifiziert und Daten aus vielen Scanfahrten zu Heatmaps aggregiert (rechts)

denen mit bestimmten Phänomenen zu rechnen ist: dies kann z.B. ein Bereich sein, in dem eine tiefstehende Sonne blenden kann, oder ein Bereich, in dem Fußgänger oft unvermittelt die Straße queren. Letzterer lässt sich mittels Daten aus dem Mobile Mapping System bestimmen. Hierzu wurden ähnlich wie im Projekt mit den Parkplatzkarten zunächst eine Objektklassifikation der 3D-Punktwolken durchgeführt und dabei allerdings Fußgänger bestimmt. Aus der Überlagerung der Positionen von Fußgängern zu verschiedenen Zeitpunkten können sog. Heatmaps abgeleitet werden, die häufiges Vorkommen anzeigen (Abb. 8, rechts).

Diese Information kann durch das autonome Fahrzeug genutzt werden, um in diesen Bereichen gezielt nach Personen zu suchen (vgl. Abb. 9, links oben). Werden diese identifiziert, ist es für künftige autonome Systeme von großer Bedeutung, dass sie ihr geplantes Verhalten an die Fußgänger kommunizieren können. In einer prototypischen Realisierung wurde am ikg ein Beamer auf dem Mobile Mapping




Abb. 9: Identifikation eines Fußgängers – Projektion eines Zebrastreifens; Projektion eines roten Fahrbahnrandes und eines Stopp-Schilds zeigt an, dass das Fahrzeug nicht anhalten wird.

Fahrzeug platziert, der den Fußgängern visuell kommuniziert, ob das Fahrzeug anhält oder weiterfährt. Im ersten Fall projiziert es einen Zebrastreifen auf die Straße, im zweiten Fall ein Stopp-Schild.

6. Zusammenfassung

Die vorgestellten Arbeiten wollen beispielhaft verdeutlichen, welche Aufgaben im Kontext der automatischen Erfassung und Analyse von Mobilitätsdaten anfallen und aufzeigen, für welche Anwendungsgebiete sie eingesetzt werden können. Von großer Bedeutung sind dabei zum einen Verfahren des Maschinellen Lernens, die für vielfältige Aufgaben der Interpretation eingesetzt werden. Darüber hinaus gewinnt die skalierbare Verarbeitung von sehr großen, heterogenen Datenbeständen (Big Data) eine zunehmende Bedeutung (Li et al., 2015).

7. Literatur

BOCK, F., D. EGGERT & M. SESTER (2015): On-street Parking Statistics Using LiDAR Mobile Mapping, Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on, p. 2812–2818.

BOCK, F. & S. DI MARTINO (2017): How many probe vehicles do we need to collect on-street parking information? – 5th IEEE International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS), p. 538–543.

BRENNER, C. (2016): Scalable Estimation of Precision Maps in a MapReduce Framework. – Proceedings of the 24th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems, p. 27:1–27:10, New York, NY, USA.

BUSCH, S., A. SCHLICHTING & C. BRENNER (2017): Generation and communication of dynamic maps using light projection. – Proceedings, 28th International Cartographic Conference: ICC 2017.

HUANG, H., L. ZHANG, L. & M. SESTER (2014): A Recursive Bayesian Filter for Anomalous Behavior Detection in Trajectory Data. – In *Connecting a Digital Europe Through Location and Place* (pp. 91–104). Springer International Publishing.

LI, S., S. DRAGICEVIC, F.A. CASTRO, M. SESTER, S. WINTER, A. COLTEKIN, CH. PETTIT, B. JIANG, J. HAWORTH, A. STEIN & T. CHENG (2015): Geospatial big data handling theory and methods: A review and research challenges – ISPRS Journal of Photogrammetry and Remote Sensing.

SCHACHTSCHNEIDER, J., A. SCHLICHTING & C. BRENNER (2017): Assessing temporal behaviour in Lidar point clouds of urban environments. – In: International Archives of the Photogrammetry – Remote Sensing & Spatial Information Sciences, vol. **42**: 543–550, DOI = 10.5194/isprs-archives-XLII-1-W1-543-2017.

SCHLICHTING, A. & C. BRENNER (2016): Vehicle localization by lidar point correlation improved by change detection. In: International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences – ISPRS Archives **41**: 703–710, DOI:<http://dx.doi.org/10.5194/isprsarchives-XLI-B1-703-2016>.